

Pregledni rad

UDK: 330.4:330.5>(497.5)

Prof. dr. sc. Vladimir Čavrak¹**SHIFT-SHARE ANALIZA ŽUPANIJA REPUBLIKE HRVATSKE****SHIFT-SHARE ANALYSIS OF THE CROATIAN COUNTIES**

SAŽETAK: Lokalno gospodarstvo županija, sastoji se od sektora s različitim potencijalima rasta. Stopa rasta pojedinih sektora ovisi o nacionalnim i lokalnim uvjetima i poticajima. *Shift-share* analiza omogućava odjeljivanje tri različite komponente rasta; nacionalne, *mix*-komponente i lokalne komponente. Rezultati analize od velikog su značenja kreatorima politike lokalnoga i regionalnoga razvoja za donošenje odluka. Analiza je rađena za 20 županija i Grad Zagreb za razdoblje 1997. - 2008. godine. Rezultati upućuju na razlike u ukupnoj lokalnoj konkurentnosti županija, kao i na razlike sektorske konkurentnosti unutar županija. Ukupno 11 županija ima djelatnosti s visokim lokacijskim kvocijentom ($Lqi > 2$), što znači usku gospodarsku strukturu lokalnih županijskih gospodarstava koja je neotporna na različite šokove. Uska gospodarska struktura osobito je izražena u županijama u kojima prevladava poljoprivreda zatim prerađivačka industrija i turizam. Najveći broj županija (12) dugoročno je ostvarilo pad lokalnih konkurentskih prednosti. Manja lokalna konkurentnost, sama po sebi, nije u čvrstoj korelaciji s obilježjem uske gospodarske strukture, ali kada dolazi simultano s negativnom *mix*-komponentom ta se veza može uočiti. Rezultati analize upućuju na pasivan odnos županija u odnosu na rast i strukturne promjene lokalnih županijskih gospodarstava. Analiza upućuje na trend postupne sektorske redistribucije županijskih lokalnih gospodarstava u korist sekundarnih i tercijarnih djelatnosti.

KLJUČNE RIJEČI: *shift-share* analiza, regionalni razvoj, lokalni ekonomski razvoj, konkurentnost.

ABSTRACT: Local economy of a county consists of industries with different growth potentials. The growth rate of a respective industry depends on national and local conditions and incentives. Shift-share analysis allows separation of three different components of growth, national, mix components and local components. Results of the analysis are of great importance to policy makers, local and regional development decision-making. The analysis was done for the 20 counties and the City of Zagreb for period 1997- 2008. Results indicate differences in overall competitiveness, local and respective industries differences in competitiveness within a county. Eleven counties have industries with high location quotient ($LQi > 2$) which means extremely narrow economic structure that is non-resistant to shocks. Narrow economic structure is dominant in counties dominated by agriculture,

¹ Redoviti profesor, Ekonomski fakultet Sveučilišta u Zagrebu

manufacturing and tourism. The largest number of counties (12) has a long-term decline of local competitiveness. Lower local competitiveness, by itself, is not in a strong correlation with mono industrial feature. However, with simultaneous combination of negative mix-components this relationship becomes important. Results of the analysis indicate a passive attitude of counties toward growth and structural changes in local economies. The analysis showed a trend of gradual industry redistribution of local economies toward secondary and tertiary activities.

KEY WORDS: *shift-share* analysis, regional development, local economic development and competitiveness.

1. UVOD

Promjena dinamike i strukture regionalnih (županijskih) gospodarstava u središtu je pozornosti kreatora lokalnih i nacionalnih politika ekonomskoga razvoja, kao i istraživača koji se bave lokalnim i regionalnim ekonomskim razvojem (Knudsen, 2000) (Krumme, 2012) (Redman, May 2004) (Traistaru & Wolff, 2002). Lokalno gospodarstvo sastoji se od poduzeća i gospodarskih sektora s različitim značajkama i potencijalima rasta. Dinamika rasta ili pada lokalnoga gospodarstva determinirana je njegovim sektorskim obilježjima. Na rast utječu razni čimbenici, kao što su; tehnološke inovacije, kapital i produktivnost rada, promjene lokalne i izvozne potražnje za proizvodima i uslugama, izravni i neizravni troškovi, kvaliteta lokalnih institucija i brojni drugi. Ovi su čimbenici nelinearno distribuirani s obzirom na sektore lokalnoga gospodarstva, što ima za posljedicu različitu dinamiku rasta ili pada pojedinih lokalnih sektora (Nazara & Hewings, 2003) (Bartik, 2004). Razlika sektorske produktivnosti u novijim je istraživanjima identificirana kao bitan čimbenik na kojemu se temelji ideja o mogućem načinu utjecaja na ukupan rast putem pametnoga upravljanja strukturnim transformacijama lokalnoga gospodarstva. Razvijena je ideja da je ukupan rast moguće potaknuti putem različitih programa i poticaja rasta manje produktivnih sektora (Rodrik, 2012) (Lin, 2012). Budući da na razvoj različitih lokalnih gospodarstava utječu različiti sektori nužno je dobro poznavanje strukture i dinamike, kao i razumijevanje komparativnih i konkurentskih prednosti pojedinih sektora lokalnoga gospodarstva.

Za donošenje odluka o politici regionalnoga i lokalnoga, kao i nacionalnoga razvoja, važno je raspolagati dobrim informacijama o sektorskoj strukturi i dinamici te konkurentskim obilježjima sektora lokalnih gospodarstava. Precizna identifikacija lokalnih konkurentskih snaga temelj je za dobru razvojnu i regionalnu politiku. S obzirom na porast regionalne divergencije u Republici Hrvatskoj važno je detektirati činjenice rasta/pada, odnosno potencijale rasta/pada pojedinih sektora, koji mogu biti nositelji lokalnoga razvoja, u ovome slučaju na razini županija. Na temelju dobrih sektorskih informacija moguće je kreirati dobre odluke o potrebi stvaranja institucionalnoga i ekonomskoga okruženja koje će pogodovati rastu sektora s velikim potencijalom rasta, odnosno koje će poticati rast produktivnosti manje produktivnih sektora.

Glavni cilj ovoga rada je identificirati sektorsku strukturu gospodarstva na razini hrvatskih županija, te identificirati ukupnu i sektorsku konkurentsku sposobnost županija. Te informacije mogu biti od velike koristi nositeljima ekonomske i razvojne politike prilikom

definiranja različitih politika rasta lokalnih gospodarstava putem upravljanja gospodarskom strukturom te prilikom definiranja strateških elemenata regionalne politike.

Ostatak rada organiziran je u četiri dijela. U drugome dijelu opisuje se postojeća literatura i dosadašnja istraživanja, u trećemu se opisuje metodologija istraživanja, u četvrtome se prikazuju i objašnjavaju rezultati istraživanja i zatim se u zadnjemu dijelu prikazuju osnovni zaključci istraživanja.

2. PREGLED LITERATURE I DRUGIH ISTRAŽIVANJA

Problemi strukture lokalnoga gospodarstva dugo su u žarištu istraživača i donositelja odluka o ekonomskoj i razvojnoj politici. Brojna literatura koja tretira ova pitanja vrlo je bogata, a odnosi se jednako na metodološko-istraživačka, kao i na pitanja praktične razvojne, posebice regionalne politike. Veća pozornost regionalnomu razvoju posvećuje se naročito od pedesetih godina prošloga stoljeća.² Međutim, kako je uočeno da intervencije u ekonomski razvoj s nacionalne razine (pristup „odozgo“) često rezultiraju suboptimalnim rješenjima, a ponekad pridonose povećanju, umjesto smanjenju regionalnih disproporcija, u zadnja dva desetljeća velik je porast literature koja obrađuje aspekte lokalnoga ekonomskoga razvoja na temelju pristupa „odozdo“³ (Blair & Carol, 2009)(Blakely & Leigh, 2010), a u novije vrijeme i literature koja se zalaže za istovremenu koordinaciju politika „odozgo“ i „odozdo“ (Pike, Rodriguez-Pose, & Tomaney, 2006).

Proučavanju strukture i rasta lokalnoga gospodarstva posvećuje se također odavno velika pozornost. U ovome radu dominantno se koristi *shift-share* analiza kao glavna metoda i metoda lokacijskih kvocijenata i analiza koeficijenata specijalizacije kao pomoćne metode.

Shift-share metoda analize regionalnoga rasta izvorno je nastala još 1940-ih, a pripisuje se Danielu Creameru (Herath, Gebremedhin, & Maumbe, 2011) (Shi & Yang, 2008). U klasičan oblik, metodu je uobličio Dunn (Dunn, 1960), a kasnije je doživjela značajne poboljšice (Knudsen, 2000) (Esteban-Marquillas, 1972) (Artige & Neuss, 2012). Unatoč brojnim rezervama i kritikama *shift-share* metoda je do danas jedna od najpopularnijih i najraširenijih metoda analize strukture regionalnoga rasta. U posljednjih četrdeset godina izrađeno je puno studija koje su koristile ovu metodu posebno u području regionalne ekonomije, političke ekonomije, urbanih studija, geografije i marketinga (Knudsen, 2000). Posebno je česta primjena bila za predviđanje regionalnoga rasta, analizu učinaka različitih

² Utemeljiteljem znanosti o regionalnom razvoju smatra se Walter Isard, a njenom utemeljenju pridonijele su njegove tri knjige: *Location and Space Economy* (1956), *Industrial Complex Analysis and Regional Development* (1959) i *Methods of Regional Analysis* (1960). On je osnivač i najznačajnijeg časopisa u ovome znanstvenome području, *Journal of Regional Science*, kojega je utemeljio 1958. (Čavrak, 2011).

³ Noviji pristupi se u teoriji i praksi imenuju sintagmom „lokalni ekonomski razvoj“. Da se ovo područje uobličilo u posebno područje ekonomske znanosti potvrđuje činjenica da su već mnoga svjetska i domaća sveučilišta u svoje nastavne planove i programe uvrstila predmet „Lokalni ekonomski razvoj“ te da se to područje izučava već i na brojnim domaćim i međunarodnim poslijediplomskim studijima. Na Ekonomskom fakultetu Sveučilišta u Zagrebu već nekoliko godina postoji poslijediplomski specijalistički studij, „Lokalni ekonomski razvoj“. Također se etabliraju međunarodni časopisi među kojima je najznačajniji „Economic Development Quarterly“ (SAGE, USA).

političkih i gospodarskih inicijativa te za razvoj strateškoga planiranja lokalnoga ekonomskoga razvoja (Selting & Loveridge, 1990). Osobito je česta primjena ove metode radi opisa regionalnoga sektorskoga rasta u nekome razdoblju te za ispitivanje konkurentnosti regionalnoga gospodarstva (Sirakaya, Uysal, & Toepper, 1995) (Knudsen, 2000) (Traistaru & Wolff, 2002) (Carluer & Gaulier, 2005) (Wilson, Chern, Ping, & Robinson, 2005) (Coulson, 2006).

Tehnika *shift-share* analize korištena je za analizu regionalnoga rasta i konkurentnosti regionalnoga gospodarstva širom svijeta. Posebno su zapažene studije koje su rađene za neke dijelove SAD-a (Nevada, West Virginia, Massachusetts) (Harris & Gillberg, 1994) (Herath, Gebremedhin, & Maumbe, 2011), zatim u Španjolskoj (Fernandez & Menendez, 2005), Kanadi, Kini, Singapuru i Europi (Esteban, 2000) (Glen, 2000) (Shi & Yang, 2008) (Traistaru & Wolff, 2002). Različite studije pokazale su da se zaposlenost, produktivnost ili neka druga mjera konkurentnosti lokalnoga gospodarstva vrlo različito kreću u različitim regijama. Težište drugih studija je bilo na istraživanju industrijske strukture različitih regija i promjena strukture u vremenu, a ovisno o raznim čimbenicima kao što je na primjer, međunarodna trgovina.

U nekim studijama rezultati *shift-share* analize korišteni su kao input za druge analize, najčešće razne regresijske analize kojima se pokušavalo dublje proniknuti u uzroke strukturnih promjena u nekome lokalnome gospodarstvu. Rezultati različitih studija korišteni su kao temelj za donošenje odluka kreatora regionalne i razvojne politike pa je metoda, bez obzira na njene slabosti, doživjela vrlo široku primjenu (Held, 2004) (Regional Industry Cluster Report, 2005). Drži se da je to jedna od najraširenijih i najpopularnijih metoda analize strukture regionalnoga rasta jer ne zahtijeva velika financijska sredstva za istraživanja, a koristi se podatcima koji su javno dostupni.

Neobjašnjivo je kako ova vrlo jednostavna, a ipak relativno uspješna metoda, nije u većoj mjeri korištena u Republici Hrvatskoj, niti kao istraživačka tema, a još manje kao analitička tehnika koja daje podlogu za donošenje odluka u domeni regionalne i razvojne politike.

Za razliku od *shift-share* analize, metode lokacijskih kvocijenata i koeficijenata specijalizacije dosta rano su zastupljene u domaćim radovima (Zdunić, 1975) (Starc, 1978) (Turčić, 1997). Većina domaćih autora, koji su se bavili regionalnim razvojem, dominantno su koristili jednostavne statičke komparativne metode usporedbe razine neke pojave u odnosu na normu koja je najčešće predstavljala nacionalni prosjek. U novijim radovima često se koristi metoda omjera (omjer minimalne i maksimalne vrijednosti neke varijable, na primjer bruto domaćega proizvoda po stanovniku u županijama).

3. METODOLOGIJA ISTRAŽIVANJA

Analizu čimbenika gospodarskoga rasta, lokalnoga ili regionalnoga, može se raditi korištenjem različitih metoda. Ovdje ćemo opisati metode koje će se koristiti u radu: metoda lokacijskih kvocijenata, koeficijent specijalizacije i *shift-share* analizu.⁴

⁴

Pored navedenih postoje i brojne druge metode analize regionalnoga gospodarstva poput: klaster analiza ili analiza lanca vrijednosti (*Value chain development*), ekonometrijski i simulacijski modeli, input-output analiza i brojne druge (Cities_Alliance, 2007). Jedan od najvećih problema u primjeni bilo koje

3.1. Lokacijski kvocijent (LQ_i)

Lokacijski kvocijent (LQ_i) je analitički alat koji se koristi za mjerenje sektorske specijalizacije neke regije ili lokalne ekonomije. Sektorska struktura lokalne ili regionalne ekonomije može se bolje razumjeti ako udio svakoga njenoga sektora u lokalnoj ekonomiji usporedimo s udjelom toga sektora u nacionalnome gospodarstvu prema ukupnome nacionalnome gospodarstvu (Blair & Carol, 2009). Lokacijski kvocijent nam pruža informaciju o većemu ili manjemu udjelu pojedinih sektora u lokalnome gospodarstvu u odnosu na prosječni nacionalni udio toga sektora.

Za izračun lokacijskih kvocijenata najčešće se koriste podaci o zaposlenosti. U slučaju Republike Hrvatske ovi su podaci dostupni u javnim izvorima (Državni zavod za statistiku Republike Hrvatske; www.dzs.hr), i to na najnižoj razini agregacije, za općine, gradove i županije, i to razvrstani po Nacionalnoj klasifikaciji djelatnosti (NKD 2002 i NKD 2007)⁵. Pored zaposlenosti često se za izračun lokacijskih kvocijenata koriste i druge veličine poput bruto domaćega proizvoda, odnosno bruto dodane vrijednosti, ali te veličine često nisu dostupne na nižim razinama dezagregacije (na primjer na razini gradova i općina). U Republici Hrvatskoj dostupni su podaci o bruto domaćemu proizvodu i bruto dodanoj vrijednosti za razinu županija, ali nisu dostupni za nižu razinu dezagregacije po subdjelatnostima pa je zbog toga nemoguće koristiti ove vrijednosti za izračun lokacijskih kvocijenata.

Lokacijski kvocijent (LQ_i) za sektor i može se računati pomoću sljedeće formule:

$$LQ_i = \frac{e_i}{N_i} \frac{et}{Nt}$$

gdje simboli imaju sljedeće značenje: e_i = zaposleni u sektoru/djelatnosti i u lokalnome gospodarstvu (općina, grad, županija), e_t = ukupan broj zaposlenih u toj regiji (općina, grad, županija), N_i = broj zaposlenih u istome sektoru/djelatnosti u nacionalnome gospodarstvu, Nt = ukupan broj zaposlenih u nacionalnome gospodarstvu (Wadley & Smith, 2003) (Blair & Carol, 2009).

Lokacijski kvocijenti mogu poprimiti sljedeće vrijednosti: (a) $LQ_i = 0$; (b) $LQ_i < 1$ i (c) $LQ_i > 1$. U slučaju da je $LQ_i = 1$ lokalno gospodarstvo ima postotak zaposlenih u određenoj djelatnosti/sektoru koji je istovjetan postotku zaposlenih u toj djelatnosti/sektoru⁶ na nacionalnoj razini. Kada je $LQ_i < 1$ postotak zaposlenih u lokalnome gospodarstvu u određenoj djelatnosti manji je od nacionalnoga prosjeka, a kada je $LQ_i > 1$ to znači da je postotak zaposlenih

metode analize jest pitanje dostupnosti kvalitetnih podataka dezagregiranih na dovoljno niskoj razini. U Republici Hrvatskoj uglavnom ne raspoložemo s takvim podacima pa korištenje *shift-share* analize dobiva na značaju jer se mogu koristiti podaci iz javno dostupnih izvora.

⁵ Vidi publikaciju Državnog zavoda za statistiku Republike Hrvatske, „Zaposlenost i plaće“, Statistička izvješća, za različite godine.

⁶ U radu se koriste pojmovi: *sektori* i *djelatnosti*, često kao sinonimi. Pojam *sektori* koristi se najčešće kao teorijski pojam jer može označiti razne sadržaje dok pojam *djelatnost* ima točno određeno značenje u skladu s Nacionalnom klasifikacijom djelatnosti (NKD). Tako će se uvijek, kada je riječ o NKD-u, koristiti pojam *djelatnost*.

u nekome sektoru lokalnoga gospodarstva veći od nacionalnoga prosjeka. Vrijednost loka-
cijskoga kvocijenta pruža nam korisnu informaciju o disproporcionalnoj strukturi zaposleno-
sti lokalnoga gospodarstva, ali nam ništa ne govori o uzrocima koji mogu biti vrlo različiti.

3.2. Koeficijent specijalizacije

Koeficijent specijalizacije (KS) vrlo je korisna mjera koja pokazuje odstupanje strukture lokalnoga gospodarstva od određenoga standarda, najčešće od strukture nacionalnoga gospodarstva. Koeficijent specijalizacije izračunava se tako da se najprije izračunaju udjeli (postotci) svakoga lokalnoga sektora u lokalnome gospodarstvu i udjeli (postotci) pojedinih sektora u nacionalnome gospodarstvu. Nakon toga, izračunavaju se razlike udjela pojedinačnih sektora lokalnoga gospodarstva prema udjelima istih sektora u nacionalnome gospodarstvu. Potom se zbrajaju samo pozitivne (ili samo negativne) razlike, a njihov zbroj predstavlja koeficijent specijalizacije (Blair, 1995) (Blair & Carol, 2009). Jasno je da je ukupan zbroj pozitivnih i negativnih razlika uvijek jednak nuli pa se u ovome slučaju koriste samo podaci o pozitivnim (ili negativnim) odstupanjima. Pri tome se pretpostavlja da su pozitivne i negativne razlike ravnomjerno distribuirane, ali u detaljnoj interpretaciji valja ipak voditi računa o tome da se pozitivne i negativne razlike uvijek moraju odnositi na različite sektore.⁷

Teorijski, koeficijent specijalizacije može poprimiti vrijednosti u rasponu od nula do 100. Ekstremna vrijednost $KS = 0$ značila bi da lokalno gospodarstvo ima sektorsku strukturu koja je potpuno istovjetna strukturi nacionalnoga gospodarstva. Vrijednost $KS > 0$ znači da je struktura lokalnoga gospodarstva različita od nacionalne strukture. Veća vrijednost, dakle, implicira veće razlike.

Koeficijenti specijalizacije različitih lokalnih gospodarstava, koja sačinjavaju neko nacionalno gospodarstvo, međusobno se razlikuju, ali se te vrijednosti obično nalaze između navedenih ekstrema. Prilikom interpretacije tog koeficijenta treba biti vrlo oprezan jer on ne daje odgovore na pitanja uzroka tih međusobno različitih vrijednosti. Vrijednost koeficijenta je samo indikativna. Ono što sa sigurnošću možemo zaključiti, jest da se lokalna struktura razlikuje manje ili više od nacionalne, ali da bi odgovorili na pitanja uzroka tih razlika, potrebno je obaviti druga dodatna istraživanja.

3.3. Shift-share analiza

Shift-share analiza je često korišten alat za analizu rasta zaposlenosti u nekome lokalnome gospodarstvu tijekom određenoga vremenskoga razdoblja (Loveridge, 1995) (Knudsen, 2000) (Wilson, Chern, Ping, & Robinson, 2005) (Carluher & Gaulier, 2005) (Artige & Neuss, 2012). Kako je lokalna zaposlenost neravnomjerno sektorski distribuirana, najprije nas zanima upravo ta distribucija strukturne promjene kroz vrijeme. Naime, u vremenu neki sektori ili djelatnosti ostvaruju brži, a neki sporiji rast. Za dublju spoznaju o značajkama lokalnoga gospodarstva nije dovoljno poznavati samo činjenice koje se odnose na promjenu

⁷ U narednom poglavlju na slici 1. prikazan je koeficijent specijalizacije za sve županije. Najveću vrijednost koeficijenta specijalizacije ima Ličko-senjska županija (28,03). Glavni uzrok velike razlike lokalne gospodarske strukture ove županije u odnosu na nacionalnu, nalazimo u vrlo malome udjelu djelatnosti prerađivačke industrije u odnosu na nacionalni prosjek i iznadprosječnome udjelu djelatnosti javne uprave u županiji u odnosu na nacionalni prosjek.

pojedinačnih sektora. Potrebna nam je informacija o dinamici pojedinačnoga sektora, ali i o dinamici strukturnih sektorskih promjena. Osim toga, vrlo je važna informacija o tome što je uzrok rasta ili pada zaposlenosti u nekome lokalnome sektoru.

Shift-share analiza ima sposobnost odjeljivanja lokalnih čimbenika rasta od nacionalnih, a to je vrlo važno za razumijevanje funkcioniranja lokalne ekonomije. Identificiranje sektora u kojima je lokalna ekonomija konkurentna omogućava nam da usredotočimo napore na djelatnosti ili sektore koji će biti uspješniji od drugih, odnosno koji mogu u budućnosti biti nositelji lokalnoga gospodarskoga rasta.

Shift-share analiza omogućava izračun konkurentnosti lokalne ekonomije i analizu lokalne ekonomske baze. Ova analiza ima sposobnost dekompozicije učinaka na lokalnu zaposlenost od strane tri različita čimbenika jer odjeljuje: (1) rast koji se može pripisati učincima nacionalne ekonomije (*nacionalni udio ili shift komponenta*); (2) rast koji se može pripisati *mix*-u brže ili sporije rastućih sektora u odnosu na prosjek, i (3) rast koji se može pripisati konkurentnosti lokalnih sektora (*lokalni udio*).

Ova tehnika olakšava usporedbu između lokalne i nacionalne ekonomije (ili usporedbu s nekom drugom lokalnom ekonomijom). Specifično, *Shift-share* analiza pomaže da u lokalnoj ekonomiji identificiramo brzo i sporo rastuće sektore u odnosu na nacionalne prosjeke. Također nam pomaže da objasnimo razlike. Na primjer: proizlaze li promatrane razlike u stopama rasta iz razlike u zatečenome *mix*-u zaposlenosti u lokalnoj ekonomiji u odnosu na *mix* zaposlenosti u nacionalnoj ekonomiji ili razlike proizlaze iz konkurentskih prednosti specifične lokalne ekonomije u odnosu na nacionalnu ekonomiju?

Izračun komponenti *shift-share* analize za pojedinačni sektor može se obaviti korištenjem sljedeće formule:

$$\Delta ei = ei[(Nk / N) - 1] + ei[(Nki / Ni) - (Nk / N)] + ei[(eki / ei) - (Nki / Ni)]$$

Korišteni simboli imaju sljedeće značenje: Δei – promjena lokalne zaposlenosti u djelatnosti i ; ei = lokalna zaposlenost u djelatnosti i na početku razdoblja; eki = lokalna zaposlenost u djelatnosti i na kraju razdoblja; Nk = ukupna zaposlenost na nacionalnoj razini na kraju razdoblja; N = ukupna zaposlenost na nacionalnoj razini na početku razdoblja; Nki = ukupna zaposlenost na nacionalnoj razini na kraju razdoblja u djelatnosti i ; Ni = ukupna zaposlenost na nacionalnoj razini na početku razdoblja u djelatnosti i (Blair, 1995) (Hoppes, 1997) (Shields, 2003) (Blair & Carol, 2009).

Shift-share analiza, dakle, dekomponira lokalnu sektorsku zaposlenost na tri komponente:

1. Nacionalni udio rasta pokazuje koliko lokalne zaposlenosti možemo pripisati rastu nacionalne ekonomije. Dakle, *nacionalna komponenta* pokazuje koliko lokalne zaposlenosti možemo očekivati pod utjecajem nacionalnoga rasta, odnosno, koliko se nacionalna dinamika rasta odražava na lokalnu ekonomiju. U prvome koraku *shift-share* analize istražujemo utjecaj nacionalne stope rasta na lokalnu ekonomiju, odnosno, koliko radnih mjesta dobiva ili gubi lokalna ekonomija na temelju utjecaja promjena na nacionalnoj razini.
2. Neki sektori generiraju brži rast zaposlenosti u odnosu na druge, dok neki gube zaposlene. „*Mix*“ komponenta odražava ove razlike na lokalnoj u odnosu na nacionalnu razinu. „*Mix*“ komponenta istražuje kako se nacionalni rast ili pad prenosi na

lokalni rast ili pad nekoga sektora. Ova komponenta prikazuje učinke specifičnih sektorskih trendova na nacionalnoj razini i njihov utjecaj na broj radnih mjesta u lokalnoj ekonomiji.

3. Rast je neravnomjeran kroz vrijeme – neki sektori i industrije rastu brže od ostalih. To je posebno potaknuto različitim lokalnim komparativnim prednostima, kao što je raspoloživost nekih prirodnih resursa, industrijske veze ili favoriziranje lokalnoga tržišta rada. *Lokalni udio* upućuje na utjecaj jedinstvenih, specifičnih lokalnih čimbenika koji utječu na lokalni rast ili pad broja zaposlenih. Lokalna komponenta pomaže da identificiramo snage i pokazuje kako lokalne konkurentske prednosti mogu pridonijeti rastu lokalne zaposlenosti.

Za izračune u okviru *shift-share* analize koriste se dostupni podaci o zaposlenosti na lokalnoj i nacionalnoj razini. Obično se uzimaju podatci za razdoblje od pet godina ili više jer se strukturne promjene događaju u srednjem i dugom roku. U ovome radu korišteni su podatci za 1997. i 2008. godinu (Zaposlenost i plaće; Statistička izvješća DZS RH). Opravdanje za ovakav izbor podataka jest u tome da je 1997. godina, prva poslijeratna godina kojom započinje tzv. „*ekonomski relevantno razdoblje*“, a 2008. je godina kojom završava razdoblje prije recesije i ekonomske krize. Razdoblja krize i recesije sama po sebi pridonose različitim strukturnim promjenama, ali koje se događaju na temelju drugačijih uzroka i procesa koji nisu predmet ovoga rada. U ovoj analizi nas je zanimalo što se događa s lokalnim gospodarstvima u duljim razdobljima prosperiteta.

U prethodnim napomenama uočavamo i prvi element za kritiku *shift-share* analize jer rezultati mogu varirati upravo zbog odabira godine s kojom ćemo uspoređivati sadašnje stanje. (Shields, 2003) (Ashby, 1968). Postoje i drugi prigovori koji se odnose na sljedeće: (a) tehnika minimizira utjecaj poslovnoga ciklusa; (b) metoda ima ograničenje jer ne pokazuje precizne uzroke komparativnih i konkurentskih prednosti; (c) analiza je osjetljiva na razlike uzrokovane stupnjem agregacije sektora.

Među važne prigovore, odnosno ograničenja ove metode, valja svakako dodati i implicitnu pretpostavku da je produktivnost rada ista u svim promatranim regijama (županijama) i svim promatranim sektorima, što znači da veća zaposlenost implicira linearno veću proizvodnju. Prilikom interpretacije rezultata dobivenih ovom metodom, mora se voditi računa o navedenim ograničenjima.

Iako je *shift-share* analiza često osporavana, ipak se uz poneke modifikacije održala kao jedan od dobrih alata za razumijevanje procesa lokalnoga ekonomskoga razvoja. Temeljna prednost *shift-share* analize je što omogućuje relativno jednostavno odvajanje lokalne od nacionalne komponente rasta pojedinih sektora lokalne ekonomije. A budući da su potrebni podaci u pravilu javno i jeftino dostupni ova metoda može biti vrlo zanimljiva teoretičarima i praktičarima lokalnoga ekonomskoga razvoja.

4. REZULTATI ISTRAŽIVANJA

4.1. Lokacijski kvocijenti

Vrijednost lokacijskoga kvocijenta pruža nam korisnu informaciju o strukturi lokalnoga gospodarstva županija. Za izračun lokacijskih kvocijenata korišteni su podaci o zaposlenosti u djelatnostima prema NKD 2007 (2010.) (Zaposlenost i plaće; Statistička izvješća

DZS RH). Analiza lokacijskih kvocijenata vrlo je korisna u pogledu pružanja odgovora na pitanje jesu li lokalna županijska gospodarstva suočena s problemom uske gospodarske strukture. To je gospodarska struktura u kojoj prevladava svega nekoliko djelatnosti (jedna do četiri, od na primjer 19 koliko ih ima u NKD-2007). Među ekonomistima koji se bave gospodarskim razvojem postoji suglasnost o tome da je povoljnija šira struktura (ravnomjernija distribucija udjela na više sektora odnosno djelatnosti) jer su takva lokalna gospodarstva otpornija na različite vanjske ili unutarnje šokove. Ti šokovi mogu biti različiti; šok recesije, šokovi izazvani diskrecijskim mjerama ekonomske politike, šokovi izazvani prirodnim nepogodama (suša, led, mraz), konkurencijski šokovi nagle liberalizacije (tržišta roba, rada ili kapitala), institucionalni šokovi i slično.

Tablica 1. Lokacijski kvocijenti po županijama Republike Hrvatske (2010.)⁸

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
Zagrebačka županija	0,89	5,31	1,15	0,85	1,22	1,44	1,41	1,20	0,43	0,40	0,36	0,34	0,73	0,33	0,78	0,99	0,41	0,39	0,84
Krapinsko-zagorska županija	0,49	1,03	1,71	1,46	0,77	1,15	0,78	0,68	0,63	0,29	0,47	0,45	0,52	0,18	0,77	1,05	1,58	0,32	0,32
Sisačko-moslavačka županija	1,26	0,89	1,59	1,48	1,52	0,71	0,64	1,00	0,35	0,25	0,50	0,66	0,38	0,55	1,36	1,04	1,18	0,65	0,62
Karlovačka županija	1,49	0,20	1,27	1,30	1,14	0,84	0,68	1,03	0,53	0,33	0,64	0,51	0,48	0,49	1,81	0,99	1,10	0,86	0,81
Varaždinska županija	0,84	0,68	2,02	0,84	0,91	1,06	0,75	0,82	0,36	0,42	0,63	0,35	0,60	0,42	0,69	0,83	1,02	0,49	0,52
Koprivničko-križevačka županija	1,85	2,58	1,82	1,62	0,55	0,81	0,75	0,90	0,34	0,22	0,88	0,11	0,73	0,48	0,67	0,98	0,83	0,62	1,12
Bjelovarsko-bilogorska županija	2,65	0,54	1,52	1,32	0,88	0,86	0,70	0,79	0,35	0,33	0,83	0,21	0,60	0,59	1,04	1,16	1,08	0,45	0,67
Primorsko-goranska županija	0,65	0,49	0,89	1,21	1,30	0,86	1,00	1,67	1,92	0,71	0,77	0,99	0,94	1,22	0,72	0,92	1,13	1,08	1,07
Ličko-senjska županija	4,12	0,89	0,42	2,42	1,73	0,75	0,65	0,81	2,33	0,26	0,52	0,30	0,34	0,50	2,14	1,21	1,01	1,40	0,92
Virovitičko-podravska županija	4,47	0,81	1,40	1,28	0,93	0,59	0,85	0,79	0,38	0,18	0,74	0,06	0,54	0,12	0,99	1,21	1,14	0,37	0,51
Požeško-slavonska županija	3,24	2,55	1,49	0,96	0,92	0,51	0,76	0,78	0,27	0,50	0,37	0,47	0,32	0,08	1,12	1,16	1,58	0,44	0,55
Brodsko-posavska županija	1,72	0,53	1,38	1,02	1,01	1,59	0,68	0,74	0,13	0,41	0,63	0,14	0,68	0,53	0,91	1,18	1,23	0,69	0,86
Zadarska županija	1,58	1,77	0,55	1,00	1,69	0,86	1,09	0,88	1,28	0,51	0,88	0,72	0,63	1,29	1,33	1,33	1,10	1,50	0,80
Osječko-baranjska županija	2,77	0,53	1,02	1,30	1,12	1,13	0,94	0,87	0,66	0,75	0,75	0,60	0,68	0,62	0,98	1,13	1,08	0,83	0,92
Šibensko-kninska županija	0,29	0,34	0,79	1,67	1,64	0,60	0,97	1,20	1,48	0,37	0,83	2,18	0,48	0,65	1,54	1,16	1,20	1,84	1,00
Vukovarsko-srijemska županija	4,74	0,34	0,81	0,93	1,60	1,07	0,83	1,00	0,31	0,31	0,32	0,32	0,50	0,33	1,52	1,35	1,14	0,49	0,51
Splitsko-dalmatinska županija	0,53	0,46	0,89	1,10	0,90	1,15	1,14	1,04	1,41	0,53	0,77	0,93	0,88	1,28	0,87	1,20	0,91	1,26	1,05
Istarska županija	0,45	0,64	1,11	0,94	1,40	0,96	0,93	0,68	2,92	0,74	0,89	1,60	0,88	1,13	0,81	0,95	0,75	1,27	0,85
Dubrovačko-neretvanska županija	0,72	0,51	0,32	0,89	1,65	1,19	0,87	1,86	3,83	0,64	0,74	0,88	0,73	1,25	1,11	1,07	0,94	1,36	1,03
Međimurska županija	0,68	0,02	2,08	0,80	0,71	1,40	0,78	0,49	0,77	0,46	0,67	0,46	0,69	0,70	0,54	0,94	0,54	0,31	0,62
Grad Zagreb	0,11	0,88	0,63	0,68	0,62	0,92	1,15	0,94	0,65	2,13	1,71	1,66	1,69	1,51	1,05	0,84	1,02	1,26	1,37

Izvor: DZS Republike Hrvatske, izračun autora.

Napomena: Osjenčani su sektori koji dominiraju u strukturi lokalnoga županijskoga gospodarstva (u pravilu pet najznačajnijih koji imaju $Lqi > 1$, odnosno manji broj ako takvih nema pet).

Analiza podataka u tablici 1. pokazuje da 11 hrvatskih županija ima vrijednost lokacijskoga kvocijenta $Lqi > 2$ u jednoj do čak četiri djelatnosti, što implicira da imaju vrlo usku gospodarsku strukturu. Čak deset županija ima vrijednost $Lqi > 2$ u samo jednoj djelatnosti, što znači da imaju izrazito usku gospodarsku strukturu. Od toga broja,


⁸ Oznake djelatnosti su sljedeće (NKD – 2007): A – Poljoprivreda, šumarstvo i ribarstvo; B – Rudarstvo i vađenje; C – Prerađivačka industrija; D – Opskrba električnom energijom, plinom, parom i klimatizacija; E – Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša; F – Građevinarstvo; G – Trgovina na veliko i na malo, popravak motornih vozila i motocikla; H – Prijevoz i skladištenje; I – Djelatnosti pružanja smještaja te pripreme i usluživanja hrane; J – Informacije i komunikacije; K – Financijske djelatnosti i djelatnosti osiguranja; L – Poslovanje nekretninama; M – Stručne, znanstvene i tehničke djelatnosti; N – Administrativne i pomoćne uslužne djelatnosti; O – Javna uprava i obrana, obvezno socijalno osiguranje; P – Obrazovanje; Q – Djelatnosti zdravstvene zaštite i socijalne skrbi; R – Umjetnost, zabava i rekreacija; S – Ostale uslužne djelatnosti.

šest županija ima $Lqi > 2$ u djelatnosti poljoprivrede, šumarstva i ribarstva (Vukovarsko-srijemska, Virovitičko-podravska, Ličko-senjska, Požeško-slavonska, Osječko-baranjska i Bjelovarsko-bilogorska). Vrijednost $Lqi > 2$ u djelatnosti prerađivačke industrije imaju dvije županije (Međimurska i Varaždinska). U djelatnostima pružanja smještaja te pripreme i usluživanja hrane $Lqi > 2$ imaju dvije županije (Dubrovačko-neretvanska, Istarska). Ovim županijama treba pridodati Grad Zagreb, koji također ima jednu djelatnost s vrijednošću $Lqi > 2$ (Informacije i komunikacije) međutim, gledano u cjelini Grad Zagreb ima čak sedam djelatnosti s $Lqi > 1,2$ pa se ne može ubrojiti u lokalna gospodarstva s izrazito uskom gospodarskom strukturom.

Ako pomnije promotrimo podatke u tablici 1. ili grafičke prikaze lokacijskih koeficijenata u prilogu, možemo zapaziti da većina županija ima problem uske gospodarske strukture u kojoj dominira nekoliko djelatnosti (najčešće jedna do četiri). Za mali broj županija bi mogli reći da imaju povoljnu, relativno široku gospodarsku strukturu (Grad Zagreb, Zadarska i Splitsko-dalmatinska županija).

4.2. Koeficijenti specijalizacije

Koeficijent specijalizacije je mjera koja pokazuje odstupanje strukture lokalnoga gospodarstva od strukture nacionalnoga gospodarstva, koje služi kao norma za usporedbu. Najveću vrijednost ovoga koeficijenta, što indicira najveće odstupanje od nacionalne strukture, pokazuju u najvećem broju iste one županije koje imaju $Lqi > 2$, dakle županije s obilježjima uske gospodarske strukture (slika 1.). To su sljedeće županije: Ličko-senjska, Međimurska, Požeško-slavonska, Krapinsko-zagorska, Varaždinska, Dubrovačko-neretvanska, Kopriivničko-križevačka, Vukovarsko-srijemska, Sisačko-moslavačka i Virovitičko-podravska.



Slika 1. Koeficijenti specijalizacije po županijama Republike Hrvatske, 2010.

Izvor: DZS Republike Hrvatske, izračun autora.

4.3. *Shift-share* analiza

Shift-share analiza omogućuje odjeljivanje tri komponente rasta lokalnoga gospodarstva: nacionalni udio, *mix*-komponentu i lokalni udio. Rezultati analize prikazani su u tablici 2. U razdoblju od 1997. do 2008. godine, mjereno brojem zaposlenih u županijskim gospodarstvima (prve četiri numeričke kolone), najveći rast je ostvaren u sljedećim županijama: Zagrebačka, Grad Zagreb, Zadarska, Vukovarsko-srijemska i Varaždinska. Jedina županija koja je u promatranome razdoblju ostvarila pad ukupnoga broja zaposlenih je Virovitičko-podravska županija, a uz nju najslabiji rast ostvarile su i: Koprivničko-križevačka, Požeško-slavonska, Bjelovarsko-bilogorska i Krapinsko-zagorska županija.

Ako promatramo dekompoziciju prethodnih promjena, možemo zapaziti da sve županije imaju pozitivnu vrijednost nacionalne komponente (peta numerička kolona u tablici 2.). To znači da su sve županije imale pozitivan rast zaposlenosti, koji se može pripisati promjenama na nacionalnoj razini.

Tablica 2. *Shift-share* analiza županija u Republici Hrvatskoj, 1997. - 2008. godina

	1997	2008	Promj	% promj	nac.	mix	lok
REPUBLIKA HRVATSKA	1003882	1238572	234690	23,38			
Zagrebačka županija	38884	63596	24712	63,55	9091	-1950	17571
Krapinsko-zagorska županija	26212	28433	2221	8,47	6128	-2870	-1037
Sisačko-moslavačka županija	34320	38668	4348	12,67	8024	-2763	-913
Karlovačka županija	27399	32749	5350	19,53	6406	-1598	542
Varaždinska županija	41612	52904	11292	27,14	9728	-3481	5045
Koprivničko-križevačka županija	27310	27911	601	2,20	6385	-3528	-2256
Bjelovarsko-bilogorska županija	25417	26776	1359	5,35	5942	-1748	-2835
Primorsko-goranska županija	86058	96210	10152	11,80	20119	211	-10178
Ličko-senjska županija	8448	10406	1958	23,18	1975	246	-263
Virovitičko-podravska županija	17392	17021	-371	-2,13	4066	-2240	-2197
Požeško-slavonska županija	15540	16252	712	4,58	3633	-1707	-1214
Brodsko-posavska županija	26832	30075	3243	12,09	6273	-1119	-1911
Zadarska županija	27185	35705	8520	31,34	6355	352	1813
Osječko-baranjska županija	66002	80580	14578	22,09	15430	-1221	369
Šibensko-kninska županija	19700	24499	4799	24,36	4606	-140	334
Vukovarsko-srijemska županija	26068	34053	7985	30,63	6094	-2107	3997
Splitsko-dalmatinska županija	95332	115410	20078	21,06	22287	2395	-4604
Istarska županija	55756	68013	12257	21,98	13035	430	-1208
Dubrovačko-neretvanska županija	28458	33276	4818	16,93	6653	341	-2176
Međimurska županija	25996	31927	5931	22,82	6078	-611	464
Grad Zagreb	283961	374108	90147	31,75	66386	23108	653

Izvor: DZS Republike Hrvatske, izračun autora.

Analiza *mix*-komponente (šesta numerička kolona tablice 2.) pokazuje učinke specifičnih sektorskih trendova nacionalne razine na lokalnu razinu. Te su nacionalne sektorske promjene imale pozitivan učinak u sedam županija: Grad Zagreb, Splitsko-dalmatinska, Istarska, Zadarska, Dubrovačko-neretvanska, Ličko-senjska i Primorsko-goranska. U osta-

lim županijama, te sektorske promjene, ostvarile su negativan učinak na lokalnu zaposlenost. Zanimljivo je zapaziti da je negativan sektorski učinak nacionalne razine ostvaren u skoro svim županijama koje imaju usku gospodarsku strukturu lokalnoga gospodarstva u kojima dominiraju poljoprivreda i prerađivačka industrija. Dakle, u promatranome razdoblju došlo je do sektorskoga restrukturiranja s negativnim predznakom u županijama koje su specijalizirane u području poljoprivrede i prerađivačke industrije.

Posebno je važno analizirati *lokalni udio* koji odražava utjecaj lokalnih konkurentskih sposobnosti (zadnja kolona u tablici 2.). Možemo zapaziti da najveći broj županija (12) ima negativnu vrijednost lokalnoga udjela, što indicira opadanje lokalnih konkurentskih prednosti. Najveći pad lokalne konkurentnosti ostvarile su sljedeće županije: Primorsko-goranska, Splitsko-dalmatinska, Bjelovarsko-bilogorska, Kopriivničko-križevačka, Virovitičko-podravska, Dubrovačko-neretvanska i Brodsko-posavska.

Manji broj županija (9) ima pozitivnu vrijednost lokalne komponente, što znači porast lokalne konkurentnosti. Najveći porast lokalne konkurentnosti ostvarile su Zagrebačka i Varaždinska županija.

Općenito, možemo zaključiti da manja lokalna konkurentnost nije čvrsto povezana s obilježjima uske gospodarske strukture, ali kada dolazi u kombinaciji s negativnom *mix*-komponentom ta veza postaje vrlo uočljiva. To znači da su one županije koje imaju obilježja uske gospodarske strukture lokalnoga gospodarstva znatno osjetljivije na procese nacionalnih strukturnih promjena (na koje u pravilu ne mogu utjecati), a u pravilu negativan utjecaj *mix*-komponente povezan je i s manjim lokalnim udjelom, odnosno s manjom lokalnom konkurentnošću (na koju lokalne zajednice djelomično mogu utjecati). Ovaj zaključak, kao i raniji o pozitivnome utjecaju nacionalne komponente rasta na sve županije, implicira zaključak o pasivnoj ulozi županija u odnosu na rast i strukturne promjene lokalnih županijskih gospodarstava. Za dublje uvide u razloge i uzroke trebalo bi provesti druga istraživanja.

Matrica u tablici 3. prikazuje se sa znakom „+“ djelatnosti u kojima lokalna županijska gospodarstva imaju pozitivnu lokalnu komponentu (lokalnu konkurentnost), a sa znakom „-“, djelatnosti u kojima je lokalna konkurentnost negativna. Osjenčana polja prikazuju prve tri djelatnosti u kojima su županije ostvarile najpovoljniju lokalnu komponentu.

Rezultati u tablici 3. upućuju na zaključak da više od 50% županija ima pozitivnu lokalnu konkurentnost u sljedećim djelatnostima: obrazovanje (16 županija), ostale usluge (14), zdravstvo (13), poljoprivreda (13), rudarstvo (12), građevinarstvo (11) i poslovanje i poslovne usluge (11). Također se može uočiti da najveći broj županija (čak 18) ima negativnu lokalnu konkurentnost u djelatnosti financijsko posredovanje jer se ta djelatnost vrlo visoko koncentrirala u Gradu Zagrebu. Ovi rezultati upućuju na trend postupne sektorske redistribucije županijskih lokalnih gospodarstava u korist sekundarnih i tercijarnih djelatnosti. Uočljivo je da među lokalno konkurentnim sektorima u većini županija nema prerađivačke industrije te da je djelatnost financijskoga posredovanja visoko koncentrirana u Gradu Zagrebu.

Tablica 3. Analiza lokalne komponente⁹ – top 3 sektora s najbržim rastom lokalne komponente¹⁰

REPUBLIKA HRVATSKA	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
Zagrebačka županija	+	-	+	+	-	+	+	+	+	-	+	+	+	-	+
Krapinsko-zagorska županija	-	0	+	-	-	+	-	-	-	-	+	-	+	+	-
Sisačko-moslavačka županija	+	0	-	+	-	-	-	+	-	-	-	+	+	+	-
Karlovačka županija	+	0	+	-	-	-	-	-	-	-	-	+	+	+	+
Varaždinska županija	+	0	+	+	+	+	+	-	-	-	-	-	+	-	+
Koprivničko-križevačka županija	-	0	+	-	-	-	+	+	-	-	-	-	+	+	+
Bjelovarsko-bilogorska županija	-	-	-	+	+	-	-	-	-	-	-	-	+	+	-
Primorsko-goranska županija	+	+	+	+	-	-	-	-	-	-	-	-	-	+	+
Ličko-senjska županija	+	-	-	-	+	-	-	+	+	-	+	+	+	+	-
Virovitičko-podravska županija	-	+	-	-	-	-	+	-	-	-	+	-	+	+	+
Požeško-slavonska županija	+	-	-	-	-	+	-	-	+	-	+	-	+	+	+
Brodsko-posavska županija	-	-	+	+	-	+	-	-	-	-	-	-	-	-	-
Zadarska županija	-	+	+	-	+	+	-	-	-	-	+	+	+	-	+
Osječko-baranjska županija	-	-	+	+	+	+	-	-	-	-	-	+	+	+	-
Šibensko-kninska županija	+	+	+	+	+	-	-	-	-	+	+	+	+	-	+
Vukovarsko-srijemska županija	+	0	-	-	+	+	+	-	-	-	+	+	+	+	+
Splitsko-dalmatinska županija	+	-	+	-	-	+	-	-	+	-	-	-	-	-	+
Istarska županija	+	-	-	+	-	+	-	-	+	-	+	-	-	-	+
Dubrovačko-neretvanska županija	+	+	+	-	-	+	-	+	-	-	+	-	+	-	+
Međimurska županija	+	0	0	+	+	-	-	+	-	+	-	-	+	+	+
Grad Zagreb	-	-	-	-	-	-	+	+	+	+	+	-	-	+	-

Izvor: DZS Republike Hrvatske, izračun autora.

5. ZAKLJUČAK

Čak 11 županija ima djelatnosti s visokim lokacijskim kvocijentom ($L_{qi} > 2$), što znači usku gospodarsku strukturu lokalnih županijskih gospodarstava koja je neotporna na različite šokove. Takva uska gospodarska struktura osobito je izražena u županijama u kojima prevladava poljoprivreda, zatim prerađivačka industrija i turizam. Najveći broj županija (12) dugoročno je ostvarilo pad lokalnih konkurentskih prednosti. Manja lokalna konkurentnost, sama po sebi, nije u čvrstoj korelaciji s obilježjima uske gospodarske strukture, ali kad dolazi simultano s negativnom *mix*-komponentom ta se veza može uočiti. Rezultati analize upućuju na pasivan odnos županija u odnosu na rast i strukturne promjene lokalnih županijskih gospodarstava. Analiza upućuje na trend postupne sektor-

⁹ U ovoj tablici prikazan je zbirni rezultat detaljne sektorske analize zadnje kolone iz tablice 2. Kako u kontekstu ove analize nisu važne precizne numeričke vrijednosti, nego samo trendovi utjecaja konkurentnosti lokalnih djelatnosti, u tablicu su radi veće preglednosti, unijete samo oznake smjera trenda.

¹⁰ Tumačenje slovnih oznaka sektora (NKD 2002.): A – Poljoprivreda, lov i šumarstvo; B – Ribarstvo; C – Rudarstvo i vađenje; D – Prerađivačka industrija; E – Opskrba električnom energijom, plinom i vodom; F – Građevinarstvo; G – Trgovina na veliko i malo, popravak motornih vozila i motocikla te predmeta za osobnu uporabu i kućanstvo; H – Hoteli i restorani; I – Prijevoz, skladištenje i veze; J – Financijsko posredovanje; K – Poslovanje nekretninama, iznajmljivanje i poslovne usluge; L – Javna uprava i obrana, obvezno socijalno osiguranje; M – Obrazovanje; N – Zdravstvena zaštita i socijalna skrb; O – Ostale društvene, socijalne i osobne uslužne djelatnosti.

ske redistribucije županijskih lokalnih gospodarstava u korist sekundarnih i tercijarnih djelatnosti.

Dobivene rezultate treba kritički promotriti i kroz problem konstituiranja županija kao jedinica promatranja. Naime, županije u Republici Hrvatskoj nisu definirane kao jedinstveni gospodarski prostori na temelju regionalne gospodarske analize, nego su definirane kao administrativno-političke jedinice na temelju političkih i/ili povijesnih kriterija. Primjena ovdje korištenih analitičkih alata, mogla bi, s gledišta njihove praktične primjene, biti još veća u slučaju logičnije gospodarske regionalne podjele nacionalnoga teritorija Republike Hrvatske.


LITERATURA

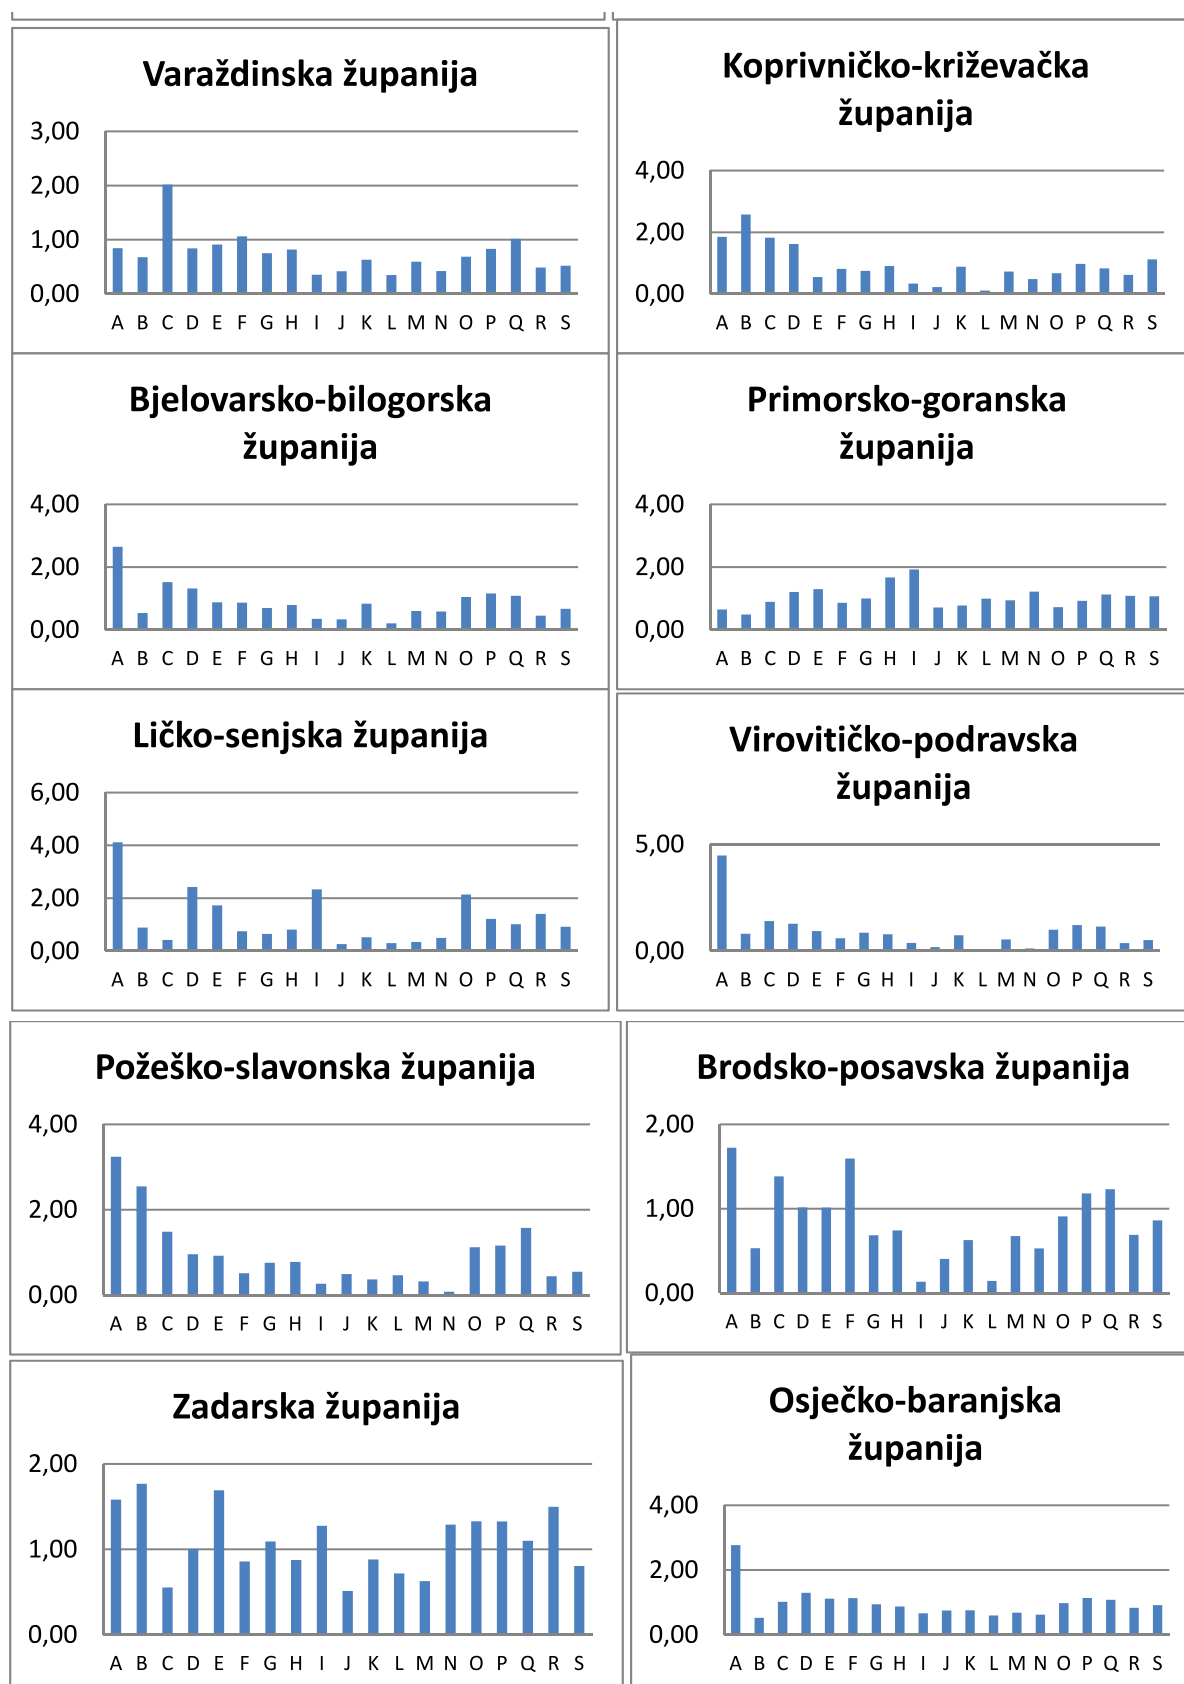
1. Artige, L., & Neuss, L. (August 2012). A New Shift-Share Method. *CREPP, Working Paper Series*, str. 1. - 16.
2. Ashby, L. D. (Jan 1968). The Shift and Share analysis: A Reply. *Southern Economic Journal (pre-1986)*; 34, 3, str. 423. - 425.
3. Bartik, T. J. (2004). Economic Development. U J. R. Aronson, & E. (. Schwartz, *Management Policies in Local Government Finance (5th ed.)* (str. 355. - 395). Washington, DC: International City/Country Management Association.
4. Blair, J. P. (1995). *Local Economic Development: Analysis and Practice*. London: SAGE Publications.
5. Blair, J. P., & Carol, M. C. (2009). *Local economic development; Analysis, Practices, and Globalization* (Second Edition izd.). Los Angeles, London, New Delhi, Singapore: SAGE Publications.
6. Blakely, J. E., & Leigh, N. G. (2010). *Planning Local Economic Development, Theory and Practice* (Fourth edition izd.). London: SAGE Publications.
7. Carluer, F., & Gaulier, G. (2005). The impact of convergence in the industrial mix on regional comparative growth: Empirical evidence from the French case. *The Annals of Regional Science*, str. 85. - 105.
8. Cities_Alliance. (2007). *Understanding Your Local Economy: A Resource Guide for Cities*. Washington, DC: The Cities Alliance.
9. Coulson, N. E. (2006). The Long Run Shift-Share: Modeling the Sources of Metropolitan Sectoral Fluctuations. *Regional Science Association and Federal Reserve Banks of New York and St. Louis*. Penn State University.
10. Čavrak, ured. (2011.). *Gospodarstvo Hrvatske*. Zagreb: Politička kultura.
11. Dunn, E. S. (1960). A statistical and analytical technique for regional analysis. *Papers of the Regional Science Association*, 6, str. 97. - 112.
12. Esteban, J. (2000). Regional convergence in Europe and the industry mix: a shift-share analysis. *Regional Science and Urban Economics*, 30(3), str. 353. - 364.
13. Esteban-Marquillas, J. (1972). A reinterpretation of Shift-Share analysis. *Regional and Urban Economics*, 2(3), str. 249. - 255.







14. Fernandez, M., & Menendez, A. (2005). Spatial Shift-Share Analysis: new development and new findings for the Spanish case. *45th Congress of the European regional Science Association*.
15. Glen, C. M. (2000). *Regional Convergence and Regional Policy in the European Union*. Valdosta: Valdosta State University.
16. Harris, T. R., & Gillberg, C. B. (1994). *A Dynamic Shift-Share Analysis of the Nevada Economy*. Reno: University of Nevada, Technical Report, UCED 94-06.
17. Held, J. R. (2004). Regional Variation and Economic Drivers: An Application of the Hill and Brennan Methodology. *Economic Development Quarterly*, 18, str. 384.
18. Herath, J., Gebremedhin, G. T., & Maumbe, B. M. (2011). A Dynamic Shift-Share Analysis of Economic Growth in West Virginia. *Journal of Rural and Community Development* 6, 2, str. 155. - 169.
19. Hoppes, B. R. (1997). Shift-share analysis for regional health care policy. *The Journal of Regional Analysis and Policy* 27(1), str. 35. - 45.
20. Knudsen, D. C. (2000). Shift-Share Analysis: further axamination of models for the description of economic change. *Socio-Economic Planning Sciences*, 34(3), str. 177. - 198.
21. Krumme, G. (2012). *Shift & Share Analysis*. Washington, DC: <http://faculty.washington.edu/ktumme/350shiftshare.html>; 29.09.2012.
22. Lin, J. Y. (2012). *New Structural Economics; A Framework for Rethinking Development and Policy*. Washington, DC: The World Bank.
23. Loveridge, S. (1995). A practical approach to shift-share analysis. *Journal of the Community Development Society*, Vol. 26 No. 1.
24. Nazara, S., & Hewings, J. D. (2003). *Towards regional growth decomposition with neighbor's effect: A new perspective on shift-share analysis*. The Regional Economics Applications Laboratory (REAL).
25. Pike, A., Rodriguez-Pose, A., & Tomaney, J. (2006). *Local and Regional Development*. London: Routledge.
26. Redman, E. (May 2004). *Another Tale of Two Cities: What Two Capital City, University Towns Can Learn From Each Other*. USA: Ray Marshall Center for the Study of Human Resources.
27. (2005). *Regional Industry Cluster Report*. Northwest Iowa, Developers Coalition.
28. Rodrik, D. (2012). Do We Need to Rethink Growth Policies? U O. Blanchard, D. Romer, M. Spence, & J. (Stiglitz, *In the Wake of the Crisis* (str. 157-167). Cambridge, Massachusetts, London: IMF; The MIT Press.
29. Selting, A. C., & Loveridge, S. (1990). Testing Dynamic Shift-Share. *www.Jrap-journal.org* 24, str. 23. - 41.
30. Shi, C., & Yang, Y. (2008). A Review of Shift Share Analysis and its Aplication in Tourism. *International Journal of Management Perspectives*; ISSN:1307-1629, 1(1), str. 21. - 30.
31. Shields, M. (2003). Understanding economic change in your community, 4: Shift-Share analysis helps identify local growth engines. *Using employment data to better understand your economy*. The Pennsylvania State University.

32. Sirakaya, E., Uysal, M., & Toepper, L. (1995). Measuring tourism performances using shift-share analysis: the case of South-Carolina. *Journal of Travel Research*, 34(2), str. 55. - 62.
33. Starc, N. (1978). *Analiza položaja privrede Zagreba u privredi Jugoslavije*. Zagreb: Ekonomski institut Zagreb.
34. Traistaru, I., & Wolff, G. B. (2002). Regional Specialization and Employment Dynamics in Transition Countries. *Working Paper, B 18-2002*, str. 1. - 32.
35. Turčić, I. (1997). *Makroekonomski razvoj županija u Republici Hrvatskoj kroz tri desetljeća (1961/1962. do 1990/1991.)*. Zagreb: Ekonomski institut; Državni zavod za statistiku Republike Hrvatske.
36. Wadley, D., & Smith, P. (2003). Straightening Up Shift-Share Analysis. *The Annals of Regional Science*, 37 (2), str. 259. - 261.
37. Wilson, P., Chern, S. T., Ping, S. T., & Robinson, E. (2005). Assessing Singapore's Export Competitiveness through Dynamic Shift-Share Analysis. *ASEAN Economic Bulletin*, Vol. 22, No 2, str. 160. - 185.
38. *Zaposlenost i plaće; Statistička izvješća DZS RH*. Zagreb: Državni zavod za statistiku Republike Hrvatske.
39. Zdunić, S. (1975.). *Kriteriji i metode regionalnog razmještaja industrije u planiranju gospodarskog razvitka*. Zagreb: Ekonomski institut Zagreb.

Prilog: Grafički prikaz lokacijskih kvocijenata po županijama





Šibensko-kninska županija**Vukovarsko-srijemska županija****Splitsko-dalmatinska županija****Istarska županija****Dubrovačko-neretvanska županija****Međimurska županija****Grad Zagreb**